

Sveučilište u Zagrebu
Prirodoslovno-matematički fakultet
Biološki odsjek

Ivana Hazdovac

Modeliranje koridora kretanja medvjeda (*Ursus arctos* Linnaeus, 1758) u Hrvatskoj

Diplomski rad

Zagreb, 2017.

Ovaj diplomski rad izrađen je u Zoologijskom zavodu Biološkog odsjeka PMF-a, pod vodstvom izv. prof. dr. sc. Perice Mustafića i izv. prof. dr. sc. Josipa Kusaka sa Zavoda za biologiju Veterinarskog fakulteta u Zagrebu, predan je na ocjenu Biološkom odsjeku Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu radi stjecanja zvanja magistra struke znanosti o okolišu.

ZAHVALE

Za početak zahvaljujem mentorima izv. prof. dr. sc. Perici Mustafiću s Biološkog odsjeka PMF-a u Zagrebu i izv. prof. dr. sc. Josipu Kusaku sa Zavoda za biologiju Veterinarskog fakulteta bez kojih izrada ovog diplomskog ne bi bila moguća. Svojim strpljenjem i pozitivnim stavom učinili su pisanje ovog rada vrlo ugodnim.

Hvala dr. sc. Ivanu Šulcu na neizmjernoj pomoći i strpljenju s radom u GIS-u i izv. prof. dr. sc. Svenu Jelaski na pomoći s Maxent-om.

Hvala svim članovima Prirodoslovno – matematičkog fakulteta u Zagrebu zbog velikog doprinosa mom obrazovanju.

Hvala svim kolegama koji su me pratili tijekom petogodišnjeg studija i sa mnom dijelili studentske brige i probleme ali i prekrasne terenske trenutke.

Hvala prijateljima, roditeljima Ani i Goranu, bratu Nikoli, kao i zaručniku Luki na velikoj podršci i potpori tijekom pisanja ovog rada, kao i tijekom cijelog studiranja.

Hvala svima koji su posredno ili neposredno sudjelovali u ostvarivanju ovog rada.

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište u Zagrebu

Prirodoslovno-matematički fakultet

Biološki odsjek

Diplomski rad

Modeliranje koridora kretanja medvjeda (*Ursus arctos* Linnaeus, 1758) u Hrvatskoj

Ivana Hazdovac

Rooseveltov trg 6, 10000 Zagreb

Medvjed (*Ursus arctos*) je najveća kopnena zvijer u Republici Hrvatskoj i jedna od tri velike zvijeri koje obitavaju na našim prostorima. Zajedno s populacijom u Sloveniji i Bosni i Hercegovini, medvjedi u Hrvatskoj čine najstabilniju zapadnu populaciju u Europi. Ovaj diplomski rad napravljen je kako bi se izradili koridori njihova kretanja u svrhu što boljeg razumijevanja biologije i ekologije medvjeda. Ti koridori mogu poslužiti prilikom planiranja budućih infrastrukturnih projekata kako bi se vodilo računa očuvanju cjelovitosti staništa ovih životinja. Programi korišteni u ovom radu su prediktivni program Maxent i ESRI ArcGIS 10.3. Pomoću njih, a na temelju stvarnih podataka o kretanju medvjeda i prostornih podataka, izrađeni su modeli koji prikazuju koridore njihova kretanja. Na taj način, moguće je dati zaključke o potrebama populacije medvjeda za cjelovitim staništem, a koji će pomoći prilikom budućeg planiranja infrastrukturnih rješenja. Harmonija između čovjeka i prirode iznimno je bitna ukoliko se želi očuvati postojanost i brojnost velikih zvijeri, a pogotovo medvjeda u Hrvatskoj. Pametno planiranje i izgradnja svih vrsta prijelaza preko autocesta umanjit će smrtnost jedinki i pomoći očuvanju cjelovitosti njihovog staništa, a što je jedan od osnovnih preduvjeta za njihov dugoročan opstanak.

(37 stranica, 13 slika, 6 tablica, 32 literaturna navoda, jezik izvornika: hrvatski)

Rad je pohranjen u Središnjoj biološkoj knjižnici

Ključne riječi: prisutnost medvjeda (*Ursus arctos*), Maxent, GIS, Least Cost Path, ekološki koridori, pogodna staništa

Voditelj 1: Dr. sc. Perica Mustafić, izv. prof.

Voditelj 2: Dr. sc. Josip Kusak, izv. prof.

Ocjenitelji: Dr. sc. Perica Mustafić, izv. prof.

Dr. sc. Sandra Radić Brkanac, izv. prof.

Dr. sc. Neven Bočić, doc.

Dr. sc. Zoran Tadić, doc.

Rad prihvaćen: 05.01.2017.

BASIC DOCUMENTATION CARD

University of Zagreb

Faculty of Science

Department of Biology

Master Thesis

Modelling of bear (*Ursus arctos*, Linnaeus, 1758) movement corridors in Croatia

Ivana Hazdovac

Rooseveltovej trg 6, 10000 Croatia

Bear (*Ursus arctos*) is the largest terrestrial carnivore in Croatia and one of three large carnivores which live in Croatia. Along with population in Slovenia and Bosnia and Hercegovina, bears in Croatia represent the most western and stable population of bears in Europe. This Master Thesis has been written with purpose of recognizing corridors for bear movement, for the purpose of better conservation of bears. These corridors are going to help in planning of future infrastructural projects by including measures which will ensure bear habitat continuity and contribute to long term survival of bears. Programs that were used in this thesis are predictive program Maxent and ESRI ArcGIS 10.3. With their use, alongside with GPS data about movement of bears and habitat data layers, I made models that show bear movement corridors. Model corridors can be used to estimate the current continuity of bear population and prevent habitat fragmentation due to future development of human infrastructure. Coexistence between humans and bears is extremely important if we want to ensure long term survival of large carnivores, especially bears in Croatia. Smart planning, which would include preservation of all types of existing crossing structures across highways and prevent future habitat fragmentation, particularly on narrow parts of movement corridors, will reduce their mortality and provide favorable conditions for longterm existence of bears.

(37 pages, 13 figures, 6 tables, 32 references, original in: Croatian)

Thesis deposited in the Central Biological Library

Key words: bear (*Ursus arctos*) presence, Maxent, GIS, Least Cost Path, ecological corridors, habitat suitability

Supervisor 1: Dr. Perica Mustafić, Assoc. Prof.

Supervisor 2: Dr. Josip Kusak, Assoc. Prof.

Reviewers: Dr. Perica Mustafić, Assoc. Prof.

Dr. Sandra Radić Brkanac, Assoc. Prof.

Dr. Neven Bočić, Asst. Prof.

Dr. Zoran Tadić, Asst. Prof.

Thesis accepted: 05.01.2017.

Sadržaj

1. UVOD	1
1.1. Biološke značajke medvjeda	1
1.2. Rasprostranjenost medvjeda u Europi i Hrvatskoj	2
1.3. Ekološki koridori	5
1.4. Prijelazi za životinje	6
1.5. Cilj rada	9
2. PREDIKTIVNI PROGRAMI U EKOLOGIJI	10
2.1. Maxent	11
2.1.1. Pristranost podataka, ROC i AUC	13
2.2. Geografski informacijski sustav	14
3. MATERIJALI I METODE	15
3.1. Prikupljeni podaci o medvjedu u Hrvatskoj	15
3.2. Priprema podataka	16
3.2.1. Priprema podataka za Maxent	18
3.2.2. Priprema podataka za GIS	19
4. REZULTATI	21
4.1. Rezultati Maxent-a	21
4.2. Rezultati modeliranja koridora u GIS-u	26
4.3. Izračun površina prikladnih staništa	30
5. RASPRAVA	32
6. ZAKLJUČCI	34
7. LITERATURA	35

KRATICE

MAXENT- Metoda maksimalne entropije (Maximum Entropy Method)

GPS - Globalni pozicijski sustav (Global Positioning System)

GIS - Geografski informacijski sustav (Geographic information system)

ROC - ROC krivulja (Receiver Operator Characteristic)

AUC - Područje ispod ROC krivulje (Area under ROC curve)

GARP - Genetski algoritam za izradu seta podataka (Genetic Algorithm for Rule Set Production)

GAMs - Generalni algebarski sustav za modeliranje (The General Algebraic Modelling Syteme)

GLMs - Poopćeni linearni model (The generalized linear model)

1. UVOD

1.1. Biološke značajke medvjeda

Medvjedi koji obitavaju u Hrvatskoj sisavci su iz reda zvijeri (Carnivora), porodice medvjeda (Ursidae), roda medvjeda (Ursus) i vrste smeđeg medvjeda (*Ursus arctos*). Trenutno u svijetu živi 8 vrsta iz porodice medvjeda: smeđi medvjed (*U. arctos*) u Euroaziji i Sjevernoj Americi, američki crni medvjed (*U. americanus*) u Sjevernoj Americi, andski medvjed (*Tremarctos ornatus*) u Južnoj Americi, bijeli ili polarni medvjed (*U. maritimus*) oko Arktika, azijski crni medvjed (*U. thibetanus*) u Aziji, sunčasti medvjed (*Helarctos malayanus*) u jugoistočnoj Aziji, usnati medvjed (*Melursus ursinus*) i veliki panda (*Ailuropoda melanoleuca*) također u Aziji. Predator Miacid koji je živio prije 25 milijuna godina zajednički je predak svim navedenim medvjedima (Huber i sur. 2008).

Američki grizli pripadnik je iste vrste kao i Euroazijski smeđi medvjed. Posebnost medvjeda, kao malo koje vrste, je sposobnost da se vanjskim izgledom prilagode na uvjete koji vladaju na njihovim staništima (Huber i sur. 2008).

Među kopnenim mesožderima medvjedi su najveći. U Hrvatskoj odrasle ženke mogu težiti u prosjeku 100 kilograma, dok mužjaci teže otprilike 50 kilograma više. Tijelo im je prekriveno dugom dlakom i gustom poddlakom. Boja dlake uglavnom je smeđa, a po hrptu često je tamnija pa i crna. Hod im je karakterističan, slično kao i čovjek, tlo dodiruju cijelim tabanima. Na prstima nogu imaju pandže (na prednjima su osobito duge 5-6 centimetara) koje im služe za pribavljanje hrane. Oštiri su zuba i ukupno ih je 42 te imaju iste značajke kao i druge zvijeri (Huber i sur. 2008).

Najčešće se hrane plodom bukve, divljom jabukom, divljom kruškom kao i mnogim drugim plodovima koje pronalaze u šumi. Vole jesti sve vrste žitarica, poput zobi, jedu i kukuruz, u voćnjacima šljive, jabuke, kruške, breskve, trešnje, grožđe i drugo voće. Također omiljen im je i šumski med pa često znaju provaljivati u pčelinjake i jesti ličinke pčela. Na taj način uzrokuju štete u poljoprivredi i smatraju se nepoželjnim gostima u bilo kojem domaćinstvu. Od životinjske hrane vole jesti lešine životinja na koje naiđu u šumi, beskralježnjake poput ličinki mrava i drugih kukaca te mladunčad divljih životinja (Huber i sur. 2008). Hranu traže po noći, obično u

područjima koja su u blizini ljudi gdje je veća otvorenost prostora što ih ostavlja podložnima krivolovu (Swenson i sur. 2000).

Medvjedi su reproduktivno aktivni u razdoblju od kraja svibnja do sredine srpnja. Spolnu zrelost dosežu u dobi od 3 do 4 godine, a životni vijek u prirodi im je između 10 i 20 godina. Prosječna dob naše lovno gospodarene populacije je oko 5 godina, a u zatočeništvu mogu doseći i do 40 godina (Bartol i sur. 2016). Poligamne su životinje i u sezoni parenja mužjaci nastoje oploditi što više ženki. Moguća je i situacija da mladunčad iz istog legla bude potomak ne samo jednog medvjeda. Graviditet traje 7 mjeseci, a medvjedići se rađaju u sredini zime slijepi i bez dlake. Vrlo su ovisni o kontaktu s tijelom majke koja ih grije i hrani mlijekom. Ono se sastoji od 22% masti i 12% bjelancevina i najslićnije je mlijeku tuljana (Huber i sur. 2008).

Zimu medvjedi provode u svojim brlozima hibernirajući, odnosno bez da išta jedu i piju. Suha trava, lišće ili razne grančice služe kao podloga za ležaj na kojem medvjed provede vrijeme brloženja. Brlozi su najčešće šupljine u stijenama koje prilagode svojim potrebama kako bi osigurali održive uvjete za sebe i svoje potomke (Huber i sur. 2008). Mladunčad je ovisna o svojim majkama u toj mjeri da ukoliko se ugrozi njihovo stanište za vrijeme zime, neizbježno ugibaju jer nisu sposobni sami preživjeti. U Hrvatskoj gotovo svake zime na taj način stradava određeni broj medvjedih legala (Huber i sur. 2008).

1.2. Rasprostranjenost medvjeda u Europi i Hrvatskoj

Medvjedi su vrlo prilagodljivi i mogu iskorištavati gotovo svaki prostor. Nekoć su obitavali u nizinskim šumama, poplavnim dolinama i sličnim područjima gdje danas obitava čovjek. Zbog te činjenice i sve većeg broja ljudi na Zemlji staništa im se sve više smanjuju i potisnuti su na područja koja ljudi uglavnom ne nastanjuju. U Europi ih danas nalazimo samo u brdskim pošumljenim područjima te u tajgama na krajnjem sjeveru. Brojnost medvjeda kontinuirano raste u zadnjih 20-30 godina, te se i vraćaju u zemlje zapadne Europe, gdje su bili gotovo istrijebljeni (Chapron i sur. 2014). Najveća populacija na zapadu Europe je ona u Kantabrij i Španjolskoj koja broji oko 120 jedinki razdvojenih u dvije skupine. Jedne od stabilnijih populacija su one u Skandinaviji s približno 2600 medvjeda, na Karpatima ih je 8000, a na Dinaridima približno 2800. Medvjedi u Hrvatskoj, zajedno s onima u Sloveniji, najzapadnija

su stabilna populacija i predstavljaju posljednji mogući spas za medvjede u zapadnoj Europi (Huber i sur. 2008). Na slici 1. vidljiva je rasprostranjenost medvjeda u Europi.



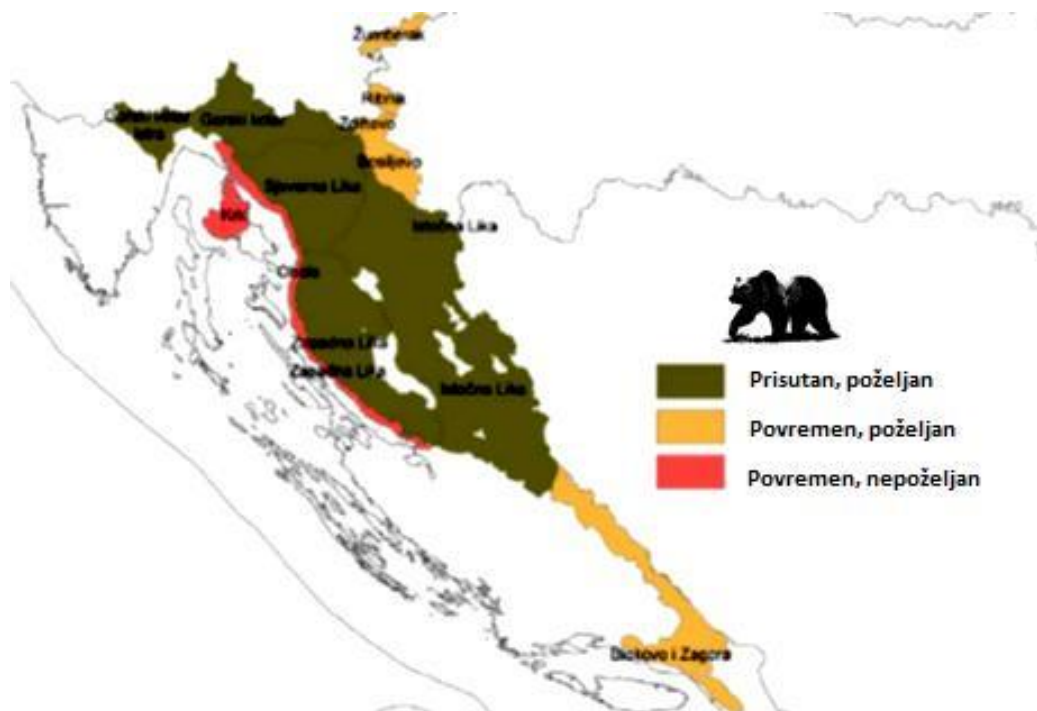
Slika 1. Rasprostranjenost medvjeda (*Ursus arctos*) u Europi

(http://ec.europa.eu/environment/nature/conservation/species/carnivores/conservation_status.htm)

Da bi stanište zadovoljilo potrebe medvjeda i kako bi oni mogli preživjeti na tom području, ono se mora sastojati od biljaka krupnog sjemena (bukva, kesten, hrast), dok su radi zaklona i pašne bitni guštika i livada (Huber i sur. 2008).

Važno je da se medvjedi mogu kretati u svim smjerovima i u zonama različitih nadmorskih visina. Prosječno dnevno prijeđu 1,6 km, a najviše do 10 kilometara. Za vrijeme života u Hrvatskoj procjenjuje se da medvjed iskoristi prostor od 250 kvadratnih kilometara, dok je za jednu populaciju potrebno oko 15.000 km² (Huber i Roth 1993). Rasprostranjenost medvjeda u Hrvatskoj prikazana je na slici 2. Ukoliko postoji zapreka koja im onemogućuje pristup


kritičnom staništu za vrijeme brloženja, može doći do negativnih posljedica u njihovim životnim ciklusima. Naime, ženke ostaju neoplođene, mladunčad ugiba zbog loših uvjeta života, raste im smrtnost zbog neadekvatne pripreme za zimu i rastu štete koje medvjedi rade na gospodarstvima jer u pokušaju da pronađu hranu za preživljavanje silaze u područja nastanjena ljudima (Huber i sur. 2008).



Slika 2. Rasprostranjenost medvjeda (*Ursus arctos*) u Hrvatskoj
(<http://www.savjetodavna.hr/savjeti/14/487/zastita-stoke-od-zvijeri/>)

1.3. Ekološki koridori

Ekološku sastavnicu ili niz takvih sastavnica koje omogućuju kretanje populacija od jedne lokacije do druge, ponajprije divljih životinja, nazivamo ekološkim koridorom. Nadležno Ministarstvo izrađuje prijedlog, a Vlada RH proglašava ekološku mrežu, odnosno sustav ekološki značajnih područja i ekoloških koridora. Pod time se podrazumijevaju područja koja bitno pridonose genskoj povezanosti populacija bioloških vrsta (Anonimus 2016). Ekološki koridori se nalaze unutar ekološke mreže te mogu biti prirodni ili umjetni. Jedna od najpoznatijih ekoloških mreža je NATURA 2000 čija članica je i Republika Hrvatska, a zadaća joj je zaštita, održavanje ili poboljšanje područja važnih za očuvanje europskih ugroženih vrsta i stanišnih tipova (Anonimus 2008). Područja u Hrvatskoj pod NATUROM 2000 prikazana su na slici 3.



Slika 3. Područja u Hrvatskoj pod NATUROM 2000 (<http://www.dzzp.hr/ekoloska-mreza/natura-2000/ekoloska-mreza-rh-natura-2000-1300.html>)

1.4. Prijelazi za životinje

Cjelokupna prometna infrastruktura, ponajviše ceste, a zatim i željeznice uvelike utječu na divlje životinje. Osim utjecaja na same životinje, utječu i na njihova staništa. Postoje mnogobrojni razlozi zašto je dobro upravljanje infrastrukturom od iznimne važnosti za očuvanje vrsta. Jedan od problema koji se mogu pojaviti je fragmentacija staništa čime se direktno utječe na pronalazak hrane jer u nedostatku hrane može doći do približavanja divljih životinja, pa tako i medvjeda naseljenim područjima (Kusak i sur. 2000). Nadalje, fragmentacijom staništa dolazi do smanjivanja područja njihovog kretanja što je važno za pronalazak partnera i reproduksijski ciklus. Uz to, neadekvatnim gospodarenjem i planom upravljanja divljih zvijeri, koje je u nadležnosti RH, može doći do stradavanja medvjeda. Najčešći uzrok su niske ograde na autocestama i državnim cestama te ih medvjedi slobodno prelaze i na taj način njihov život biva ugrožen (Huber i sur. 2002).

Kada je riječ o velikim životinjama (medvjed, vuk, ris, jelen) potrebno je napomenuti kako navedene životinje koriste prilično velika područja te je zbog toga planiranje budućih prijelaza i prolaza potrebno napraviti u što ranijoj fazi projektiranja same trase prometnice. U praćenju i procjenjivanju struktura za prelaženje divljih životinja upotrebljavaju se brojne metode uključujući tragove na prirodnoj i umjetnoj podlozi, automatske kamere, video kamere, brojači, radio-telemetrijsko praćenje, obilježavanje i ponovno hvatanje te ukupna pristupnost informacija (Huber 2002).

Brojne međunarodne konvencije (CITES, Bernska konvencija, NATURA 2000 i Direktiva o staništima) sadrže precizne i ograničavajuće uvjete koje svaka država treba zadovoljavati u zaštiti vrsta. Poznavanjem, uvažavanjem i predviđanjem potreba divljih životinja moguće je svesti negativne utjecaje prometnica na najmanju moguću mjeru (Huber i sur. 2002).

Postoji pet vrsta objekata koji se grade na autocestama, a koji uz svoju temeljnu funkciju mogu imati i važnu ekološku funkciju: propusti za vodu, prolazi, prijelazi, vijadukti, mostovi i tuneli. Propusti za vodu služe za propuštanje vode s jedne strane autoceste na drugu, a od životinjskih vrsta najviše ih koriste vodozemci, a ponekad i neki mali sisavci. Prolazi se grade na dijelovima autoceste koji su u nasipu, a koriste se za povezivanje postojeće prometnice i putova koji se presijecaju izgradnjom autoceste. U najvećoj mjeri njima prolaze vodozemci, ali i poneke velike

životinje, npr. jelen. Ukoliko se pokaže da prolaz koriste i veće životinje, potrebno ga je prilagoditi i po potrebi proširiti. Prijelazi imaju istu namjenu kao i prolazi, no razlika je ta što se prijelazi grade iznad autoceste (Huber i sur. 2002). Bitna stavka je osigurati minimalno 2 metra prostora na početku i kraju svakog prijelaza, tj. s jedne i druge strane autoceste. Isto tako, bitno je tzv. „zelenim ogradama“ usmjeriti kretanje životinja prema prijelazu. Uz to, bitno je prijelaz uklopiti u okoliš, tj. da bude što sličniji prirodnom staništu, s dovoljno zelenila i drveća kako bi životinje njime prolazile (Huber 2002).

Vijadukti se grade u slučajevima kad se prilikom trasiranja autoceste savladavaju prirodne depresije u terenu i kada je optimalno da se problem depresije riješi umjetnim objektom, a ne nasipom. U slučaju da se kao prepreka savladava vodotok ili rijeka grade se mostovi. Mostovi i vijadukti u pravilu omogućavaju nesmetano prolaženje svih vrsta životinja i kod njihove izgradnje najviše pažnje treba posvetiti uređenju samih objekata. Kako bi se što manje narušila prirodna slika krajolika potrebno je smanjiti utjecaj buke i osvjetljenja na način da se vijadukti i mostovi grade tako da im je visina na polovini minimalno 15 metara (Huber 2002). Uz infrastrukturne, važno je naglasiti da na našim autocestama postoje i zeleni mostovi koji služe kao prijelaz za životinje. Naime, riječ je o specijaliziranim objektima koji omogućuju sigurno i nesmetano prelaženje životinja preko autocesta. Riječ je o umjetnim tunelima nasipanim zemljom koji bi se trebali izgraditi da se što bolje uklapaju u prirodno stanište životinja (Anonimus 2016). Prvi zeleni most u Hrvatskoj izgrađen je 1999. godine na autocesti Zagreb - Rijeka kod mjesta Dedin (Gužvica i Šver 2006). Trenutno na hrvatskim autocestama postoji 11 zelenih mostova, od kojih je najdulji Osmakovac s duljinom od 200 metara (Gužvica i Šver 2006). Na slici 4. prikazan je primjer zelenog mosta u Hrvatskoj.



Slika 4. Primjer Zelenog mosta na autocesti A1 (<http://www.geografija.hr/hrvatska/utjecaj-izgradnje-autocesta-na-fragmentaciju-stanista/>)

Tuneli kao zadnji promatrani objekt predstavljaju idealno rješenje za prijelaz životinje preko autoceste (Huber 2002), jer se najbolje uklapaju u okoliš i ukoliko su dovoljno dugi, životinje neće čuti buku prometa te ga neće percipirati kao prepreku slobodnom kretanju u prirodi.

Svaka od navedenih vrsta prometne infrastrukture zahtijeva konstantno praćenje kako bi se saznala njihova iskorištenost i prilikom planiranja budućih objekata implementirala rješenja koja će smanjiti njihov negativan utjecaj na staništa divljih životinja.

Osim spomenutih objekata, bitna stavka za očuvanje divljih životinja, pa tako i medvjeda su ograde. One bi trebale biti na autocestama kao i na nekim važnijim državnim cestama kako ne bi došlo do smrtnosti životinja. Postoje mnoge vrste ograda koje bi se mogle postaviti: električne, kemijske, akustične, optičke i mehaničke. Upravo je njihova izgradnja od iznimne važnosti za medvjeda, jer se on lako penje po ogradi od žičane mreže, a lako i potkopa prolaz. Zbog tog razloga, ograda treba biti dovoljno visoka, ukopana i učvršćena u zemlju. Na posebno osjetljivim područjima trebaju postojati dvije do tri dodatne žice tzv. "električnog pastira". Bez tih uvjeta nije moguće osigurati da medvjed, kao ni ris ili vuk ne izađu na samu cestu (Huber 2002).

1.5. Cilj rada

Cilj ovog diplomskog rada je modeliranje koridora kretanja medvjeda u Republici Hrvatskoj. Kako bi se to postiglo, upotrijebit će se podaci o kretanju medvjeda prikupljeni pomoću GPS odašiljača od 2008. godine do početka 2016. godine te GIS podloge bitnih komponenti staništa medvjeda. Koristit će se prediktivan program Maxent za dobivanje modela vjerojatnosti pojavljivanja medvjeda i program ESRI ArcGIS koji će pomoći u modeliranju koridora kako bi se bolje razumjelo kretanje populacije medvjeda na našim prostorima. Svrha ovog modeliranja je očuvanje cjelovitosti staništa za populaciju medvjeda u Hrvatskoj. Rezultati ovog rada mogu pomoći pri planiranju budućih infrastrukturnih zahvata u staništu medvjeda, a koji će poštivati koridore kretanja i voditi računa o zaštiti postojećih „uskih grla“, tj. prijelaza na prepoznatim koridorima.

2. PREDIKTIVNI PROGRAMI U EKOLOGIJI

U ovom diplomskom radu koristit će se prediktivan program Maxent, kao i geografski informacijski sustav (GIS).

Prediktivni modeli omogućuju procjenu ishoda u biologiji, ekologiji i u drugim znanstvenim područjima. To su modeli koji povezuju prikupljene podatke sa staništima i drugim varijablama, npr. s klimom, reljefom, infrastrukturom i dr. (Selanec 2012). Posebno su važni modeli geografske rasprostranjenosti vrsta zbog zaštite samih vrsta (Graham i sur. 2004), a u ovom slučaju medvjeda. Uz zaštitu vrsta, znanstvenici su uvidjeli da uz pomoć modela za procjenu mogu istraživati invazivne vrste, utjecaje klimatskih promjena i dr. (Graham i sur. 2004).

Prediktivne metode izrađuju modele pomoću jednostavnih i preciznih matematičkih formula. Jedna od poznatih metoda je GARP koja se često se upotrebljava zbog korištenja samo prisutnih vrsta. Također, programi koji u obzir uzimaju samo podatke o prisutnim vrstama su BIOCLIM i DOMAIN. BIOCLIM predviđa prikladne uvjete, tj. područja predstavljajući raspone u svakoj dimenziji okoliša, dok DOMAIN koristi metričku sličnost gdje se predviđeni indeks dobije izračunavanjem minimalne udaljenosti u okolišu za svaku zabilježenu vrstu (Phillips i sur. 2006). No, iako podatke o prisutnosti vrsta uglavnom imamo, podaci o odsutnosti vrsta često nisu dostupni zbog težine prikupljanja, a posebno za loše uzorkovana tropska područja gdje je modeliranje staništa od iznimne vrijednosti za očuvanje okoliša (Anderson i sur. 2002.). U tom slučaju, koriste se metode kao što su GLMs i GAMs koje izrađuju modele sa podacima prisutnih i odsutnih vrsta, uzimajući popratni piksel kojeg koriste kada nedostaju podaci o odsutnosti vrsta (Phillips i sur. 2006).

Cilj svake metode za modeliranje područja je predvidjeti prikladnost okoliša za određene vrste kao funkciju zadanih komponenti staništa (Phillips i sur. 2006). Okolišni uvjeti na trenutnim lokalitetima predstavljaju uzorke iz realnih niša. Također, dokazano je da je modeliranje poboljšano u regijama na većim geografskim prostorima, npr. na cijelom području Hrvatske, a ne samo na jednom dijelu. Upravo to je iznimno bitno jer modeli dobiveni prediktivnim metodama opisuju prikladnost u ekološkom smislu, no to se obično projicira na nekom geografskom prostoru. Uz to, modelirajući programi bitni su jer primjerice pogodna područja koja nisu naseljena zbog nekih biotičkih čimbenika se mogu vrlo lagano identificirati i ukloniti iz predviđanja. No, unatoč pozitivnim stranama metoda, postoje i neki problemi koje ne smijemo

zanemariti. Prvo, istraživana područja mogu biti pristrana, npr. često su korelirana sa prisutnošću cesta, rijeka i dr., a to se treba izbjeći. Uz to, pogreške se mogu javiti zbog nedostatka geografskih detalja (ukoliko su podaci stariji) ili zbog pogrešne identifikacije vrsta. Također, nedostatak dovoljnog broja podataka može dati nepouzdanu i netočnu rezultate. Na kraju, pogreške se mogu dogoditi i s varijablama, zbog nepreciznosti u klimatskim modelima korištenim za generiranje klimatskih varijabli (Phillips i sur. 2006).

Kao što je navedeno iznad, trenutno postoje različite metode i programi za modeliranje koji daju različite rezultate te je potrebno izabrati pravi, ovisno o tome koji je predmet promatranja. U ovom diplomskom radu koristit će se Maxent koji u odnosu na druge, starije metode bolje izrađuje modele (Elith i sur. 2006, Phillips i sur. 2006) te je s obzirom na samu problematiku diplomskog rada pogodniji za izradu očekivanog modela.

2.1. Maxent

Maxent je program čiji se model i rezultati temelje na maksimalnoj entropiji. Jedan je od najpoznatijih programa za procjenu jer u odnosu na druge programe bolje izrađuje modele koji daju točniju procjenu promatranih varijabli (Merow i sur. 2013). Upotrebljava se za modeliranje staništa i distribucije vrsta te program koristi samo podatke o prisutnim vrstama (*presence-only data*). Raspoložive informacije o nalazu pripadnika vrste prikazane su kao skup realnih varijabli (Phillips i sur. 2006). Upravo zbog korištenja podataka samo prisutnih vrsta za koje su potrebne trenutno poznate činjenice i neke varijable (klimatske, topografske i dr.) Maxent je najpogodniji program za ovakav tip istraživanja. Maxent, za razliku od drugih programa koji zahtijevaju i korištenje podataka gdje vrste nisu prisutne (*absence data*), koristi samo empirijske podatke čime pojednostavljuje proces istraživanja. Naime, prikupljanje podataka gdje vrste nisu prisutne ponekad nije moguće ili ih je teško i skupo prikupiti (Elith i sur. 2006).

Kao ulazni podatak Maxent uzima popis prisutnih vrsta zajedno s ekološkim varijablama (površina šuma, pašnjaka), kao i one varijable na koje reljef ima utjecaj (infrastruktura, ceste, udaljenost od naselja). Uz to, korisnik određuje i krajolik koji je podijeljen u mrežu ćelija, tj. piksela koji čine prostor na kojem se definira vjerojatnost pojave vrste (Phillips i sur. 2006). Iz tog krajolika, Maxent izvlači uzorak lokacija prisutnih vrsta, na temelju toga radi model i uspoređuje ih s lokacijama na kojima te vrste zaista obitavaju (Merow i sur. 2013).

Ideja Maxenta je procijeniti vjerojatnost distribucije i to na način pronalaska distribucije maksimalne entropije (Phillips i sur. 2006). Pravilo maksimalne entropije govori da bi model trebao biti odabran na način da bude što sličniji očekivanjima, kao i da je konzistentan s podacima (Jaynes 1957, Dudík i sur. 2005). Da bi osigurali predviđanja konzistentna podacima, Maxent modelira momente predviđanja (varijanca, aritmetička sredina) kako bi odgovarali empirijskim (prikupljenim) podacima (Merow i sur. 2013). Prednosti i nedostaci Maxent-a nad drugim programima prikazani su u tablici 1.

Tablica 1. Prednosti i nedostaci Maxent-a (prema Phillips i sur. 2006)

PREDNOSTI	NEDOSTACI
Zahtijeva samo podatke o prisutnosti vrsta zajedno s varijablama i na temelju njih izrađuje model	Manje smjernica za upotrebu i manje metoda za procjenjivanje pogrešaka za razliku od statistička metoda kao GLM ili GAM
Prilikom modeliranja mogu se koristiti kontinuirani i kategorijski podaci te se mogu uključivati interakcije između varijabli	Potrebno je daljnje usavršavanje programa kako bi se izbjeglo preklapanje između varijabli
Deterministički algoritmi su tako razvijeni da omogućavaju optimalnu distribuciju vjerojatnosti pojavljivanja vrsta	Maxent koristi eksponencijalan model vjerojatnosti što ponekad može dati vrlo velike predviđene vrijednosti
Omogućuje interpretaciju svake varijable i njihov utjecaj na okoliš	
Maxent je generativni pristup što može biti prednost kada je količina podataka smanjena	

Bez obzira na gore navedene nedostatke Maxent se zbog svojih dobrih značajki pokazao kao izvrstan program za ovaj diplomski rad.

2.1.1. Pristranost podataka, ROC i AUC

Koristeći Maxent, jedna od najvažnijih zadaća je dokazati kako su dobiveni podaci nepristrani (Dudik i sur. 2005). Da bi se to postiglo potrebno je da distribucije uzorkovanja i distribucije vrsta nisu u korelaciji. Primjerice, ponekad se uzorkovanje obavlja na područjima bližim čovjeku iz razloga lakše dostupnosti (Dudik i sur. 2005). No bez obzira na to, mogućnost pogreške se smanjuje u modeliranju staništa jer neke podatke sa sigurnošću znamo: udaljenost od naselja, cesta i slično. Također, očekuje se da nepristrani modeli ne koriste nikakvo znanje o pristranosti odabira uzorka tijekom testiranja, a to je posebno važno u izradi modela staništa jer se modeli ponekad mogu primjenjivati na drugu regiju ili različite klimatske uvjete (Dudik i sur. 2005). Naime, kada postoji veliki broj podataka, koristit će se prostorno filtriranje kako bi se smanjio njihov broj u prevelikom uzorku i na taj način izradio model koji će biti statistički značajan (Kramer-Schadt i sur. 2013).

Uz gore navedena obilježja, ponekad dolazi do prostorne pristranosti koja dovodi do nepoželjne pristranosti okoliša, a sve zbog prevelike zastupljenosti pojedinih okolišnih čimbenika. Ukoliko je velika razlika između pojave evidencije i pozadinskih podataka može doći do kreiranja netočnih modela (Dudik i sur. 2005). Iz navedenih razloga od iznimne važnosti je dokazati kako su podaci o pojavi vrsta nepristrani, a to se radi na način da se izradi poseban dokument u GIS programu koji će poslužiti za daljnje analize kao i dati što ispravniji model.

ROC (Receiver Operating Characteristic) i AUC (Area Under Curve) su vrlo bitni za ocjenu uspješnosti modela te se prikazuju pomoću grafikona. ROC je krivulja koja se najčešće koristi za vizualizaciju izvedbe binarnog klasifikatora, a AUC je najbolji način da se sumira učinkovitost modela s jednim brojem (Elith i sur. 2011). Glavnu prednost ROC analize predstavlja površina ispod krivulje (AUC) koja daje mjerilo uspješnosti modela neovisno o pragu („threshold“) (Phillips i sur. 2006). AUC krivulja nam ponajviše može pomoći u usporedbi s drugim modelima te je jako korisna kada imamo više modela koje treba usporediti (Young i sur. 2011). Vrijednost AUC krivulje kreće se u rasponu od 0 do 1. Vrijednost od 0.5 govori kako model nije bolji od nasumičnog, dok vrijednosti iznad 0.5 i što bliže 1 pokazuju kako je model reprezentativniji (Phillips i sur. 2006).

2.2. Geografski informacijski sustav

Geografski informacijski sustav (GIS) je program za obradu i analizu prostornih podataka. Radi se o računalnom sustavu koji je sposoban za integriranje, spremanje, uređivanje, analiziranje (Halavuk 2013) i prikazivanje geografskih informacija u tekstualnom (alfanumeričkom) i grafičkom obliku (Toskić 2015). GIS se temelji na znanjima iz geografije, kartografije, informatike i matematike. Sastoji se od hardvera, softvera, podataka i njihove primjene. Omogućuje nam mnogobrojne statističke i prostorne analize, kao i izradu baze podataka s informacijama o nekom području (Selanec 2012). Upravo zbog mogućnosti povezivanja prostornih podataka s ekološkim parametrima GIS je prikladan i za upotrebu u biologiji i ekologiji. Također, na temelju povezivanja podataka s varijablama možemo donijeti zaključke o njihovoj korelaciji, izraditi karte i modele za ekologiju područja našeg interesa (Selanec 2012).

Postoji više tvrtki koja su se specijalizirala za izradu GIS programa, a u ovom radu korišten je ArcGIS kojeg je izradila tvrtka ESRI. Glavne sastavnice ArcGIS-a su: ArcMap, ArcCatalog i ArcView, dok ArcGIS Desktop koji je upotrijebljen u istraživanju uključuje skup integriranih aplikacija: ArcMap, ArcCatalog i ArcToolbox. Najvažniji je ArcMap koji pomaže vizualizirati podatke te uključuje i određene mogućnosti analiza (Toskić 2015).

Dvije metode koje se koriste za pretvorbu stvarnog svijeta u oblik pogodan za kodiranje u računalnim bazama podataka su rasterski i vektorski oblik. Kod rasterskog oblika piksel je nositelj informacije i entitet se stvara grupiranjem ćelija napravljenih po principu mozaika, dok je vektorski oblik skup x i y koordinata. Iz rasterskih i vektorskih podataka moguća je pretvorba iz jednog oblika u drugi korištenjem ArcToolbox-a (Toskić 2015). Bitno je spomenuti i pojam reklasifikacije koji je korišten u ovom radu. Naime, reklasifikacija rastera se koristi kako bi kategorije načina iskorištavanja zemljišta mogli prikazati ocjenskim vrijednostima (Toskić 2015).

Rezultati dobiveni GIS analizama često su korisni i za buduće projekte kako bi upravljanje postojećom i budućom infrastrukturom bilo što učinkovitije.

3. MATERIJALI I METODE

3.1. Prikupljeni podaci o medvjedu u Hrvatskoj

Krajem 1960-ih godina u Sjedinjenim Američkim Državama počele su se koristiti moderne metode istraživanja prostorne ekologije divljih životinja, pa tako i medvjeda, putem radiotelemetrije. Prvi projekt telemetrijskog istraživanja medvjeda u Europi započeo je tijekom 1970-ih u gradu Trentu u sjevernoj Italiji gdje su bile obilježene dvije jedinke. U Hrvatskoj, drugi po redu u Europi, projekt je započeo 1981. godine (Huber 2001). Kako bi se na ispravan način istražilo kretanja populacije medvjeda potrebna je dobra priprema i dovoljno vremena da bi se donijeli ispravni zaključci. Za potrebe ovog diplomskog rada i analizu upotrijebljeni su podaci od rujna 2008. godine do veljače 2016. godine. Riječ je o GPS koordinatama kretanja medvjeda gdje su podaci prikupljeni pomoću telemetrije, stavljanjem ogrlica (Huber i sur. 2002). Medvjedi su najčešće hvatani za nogu zamkom od čeličnog užeta aktiviranom nagaznom oprugom. Bili su privučeni životinjskim lešinama ili omamljeni puškama i puhaljkama (Huber 2001). Nakon stavljanja ogrlice, medvjedu se izmjerila duljina, težina, opseg vrata, glave i sl. (Huber 1997) te se uzeo uzorak krvi i urina za laboratorijsko testiranje. Na slici 5. prikazano je postavljanje ogrlice medvjedu i mjerenje fizičkih značajki.



Slika 5. Postavljanje ogrlice medvjedu i mjerenje veličine prednje šape (http://www.ldklek-ogulin.hr/?subaction=showfull&id=1255967044&archive=&start_from=&ucat=&)

Ogrlica u sebi sadrži GPS prijemnik s kojim određuje lokaciju medvjeda i mobitel pomoću kojega te podatke svaka dva sata šalje putem SMS poruke u centar za praćenje kretanja (Anonimus 2009). GPS podaci medvjeda dobiveni putem odašiljača daju podatke o kretanju medvjeda u svakom trenutku. Taj period praćenja traje od 2 do 3 godine te nakon toga posebnim signalom ogrlica sama otpada (Huber i sur. 2002).

Na taj način se određuju lokacije medvjeda svaka dva sata, kao i način na koji medvjedi iskorištavaju svoj prostor te infrastrukturne objekte i koliko često prelaze autoceste. Primjerice, tijekom ljeta 2015. godine tri od četiri medvjeda koja su u tom trenutku bila praćena prešli su autocestu (Huber i sur. 2002). Upravo iz tog razloga, bilo je potrebno istražiti koliko su prijelazi za životinje korisni i kako bi se u budućnosti neke stvari mogle promijeniti i usavršiti.

3.2. Priprema podataka

U ovom diplomskom radu korišten je set lokacija medvjeda s GPS koordinatama te podaci o komponentama staništa u digitalnom obliku, kao i GIS slojevi (Tablica 2). Iako je prvotno planirano 16 slojeva, s obzirom da je riječ o medvjedu, neki od slojeva nisu bili značajni te nisu iskorišteni u radu. Tablica 2 prikazuje korištene ekološke varijable, GPS koordinate kao i vektorske karte infrastruktura.

Tablica 2. GIS slojevi korišteni za Maxent i GIS

	NAZIV	IZVOR PODATAKA	TIP PODLOGE
1.	Digitalni model površine šuma	Kusak J., Singer D., Desnica S. (2005): Vjerojatnost pojavljivanja vuka u Hrvatskoj. LIFE III CroWolf projekt, GIS karta, DZZP.	Raster
2.	Digitalni model nadmorske visine	http://freegeographytools.com/2010/free-30-meter-resolution-elevation-data-for-most-of-theworld-from-aster-gdem	Raster
3.	Digitalni model cesta	Kusak J., Singer D., Desnica S. (2005): Vjerojatnost pojavljivanja vuka u Hrvatskoj. LIFE III CroWolf projekt, GIS karta, DZZP.	Raster
4.	Digitalni model udaljenosti od cesta	Kusak J., Singer D., Desnica S. (2005): Vjerojatnost pojavljivanja vuka u Hrvatskoj. LIFE III CroWolf projekt, GIS karta, DZZP.	Raster
5.	Digitalni model udaljenosti od naselja	Ministarstvo kulture (2004): Karta staništa Republike Hrvatske. Izradio: OIKON d.o.o., Institut za primijenjenu ekologiju	Raster
6.	Karta prisutnosti medvjeda	Veterinarski fakultet u Zagrebu	Vektor
7.	Karta s prijelazima za životinje	Veterinarski fakultet u Zagrebu	Vektor
8.	Karta autocesta u RH	Veterinarski fakultet u Zagrebu	Vektor
9.	Karta sa stalnim i povremenim obitavanjem medvjeda	Veterinarski fakultet u Zagrebu	Vektor
10.	Karta s geografskim regijama	Veterinarski fakultet u Zagrebu	Vektor

Prije uvrštavanja gore navedenih slojeva i karte prisutnosti medvjeda u Maxent bilo je potrebno prilagoditi formate ulaznih podataka na Maxent-u kompatibilan način. „Gridove“ je bilo potrebno prebaciti u ASCII format (.asc) pri čemu nam je ArcMap poslužio za pretvorbu. Isto tako, Excel tablicu s GPS koordinatama kretanja medvjeda bilo je potrebno pretvoriti u *comma delimited format* (.csv) jer ih u protivnom Maxent ne bi mogao prepoznati.

3.2.1. Priprema podataka za Maxent

Za pokretanje programa Maxent bila je potrebna tablica s koordinatama, tj. lokacijama, kao i rasteri dobiveni pretvorbom u ArcMap-u. Rasteri površine šuma, nadmorske visine, cesta, udaljenosti od ceste i udaljenosti od naselja poslužile su kao ekološke varijable. Za svaku varijablu zasebno je odabran kategorijski ili kontinuiran tip, ovisno o kakvim slojevima je bila riječ (Young i sur. 2011). Primjerice, ukoliko se kao jedna od varijabla koristi tip vegetacije, potrebno je izabrati kategorijski tip, no ukoliko se radi o nadmorskoj visini ili primjerice količini oborina, treba izabrati kontinuirani tip (Dudik i sur. 2005). Iz tog razloga, izabran je kontinuirani tip za sve GIS slojeve. Uz to, važno je napomenuti da svi odabrani slojevi su morali imati istu veličinu ćelija i projekcijski sustav kako bi se u Maxent-u moglo provesti modeliranje (Young i sur. 2011).

Prilikom odabira postavki uzorka, koristilo se 25% slučajnih podataka uzetih u test uzorak. Ova postavka omogućila je zadržavanje određenog postotka podataka koji se koriste za ocjenjivanje učinkovitosti modela. Ukoliko nedostaju test podaci, model će iskoristiti podatke za modeliranje, tzv. *Training data* kako bi ocijenio model. *Training data* su podaci koji nam pokazuju koliko dobro Maxent objašnjava ulazne podatke kako bi model bio uspješan, dok *Test data* prikazuju koliko dobro Maxent predviđa neovisne podatke. Pomoću ta dva seta podataka, Maxent daje izlazne podatke temeljene na jednim ili drugim uzorcima. Uključivanjem određene postavke kod koje od podataka za modeliranje se uzima određeni postotak koji se koristi za ocjenjivanje (Young i sur. 2011). Isto tako, takva postavka omogućuje programu da radi osnovne statističke analize. Uz to, broj iteracija uvećan je s 500 na 5000, što omogućuje modelu da ima odgovarajuće vrijeme za konvergenciju. Ako model nema dovoljno vremena za konvergenciju, koja se pokazuje u obliku broja iteracija, taj model mogao bi krivo predvidjeti međusobne odnose (Young i sur. 2011).

3.2.2. Priprema podataka za GIS

Kako bi se pravilno modelirali koridori u ArcMap-u korištene su varijable iz Tablice 2, karta s prijelazima za životinje i karta s autocestama. Budući da je riječ o vektorskim podacima, bilo ih je potrebno pretvoriti u rasterski tip podataka kako bi se iskoristila procedura „Least Cost Path“ koja prepoznaje koridore na temelju ulaznih podataka koji su u ovisnosti jedni o drugima. „Least Cost Path“ određuje najbližu moguću udaljenost između dvije nasumično odabrane točke s obzirom na autoceste, prijelaze i model rasprostranjenosti. Kako bi se pravilno izradili koridori potrebna su 2 koraka: „Cost Distance“ i „Cost Path“. No, prije tih koraka bilo je potrebno ulazne podatke prilagoditi opcijama kako bi ih program prepoznao. Od ulaznih podataka izradila sam rastere koji su potom spojeni u jedan zajednički. Novonastali raster sam zatim reklasificirala u devet kategorija. Prilikom pretvorbe i reklasifikacije bilo je važno utvrditi u koliko klasa će se reklasificirati rasteri i kakvu će vrijednost imati pojedini ulazni podatak. Način na koji se raster reklasificirao prikazan je u Tablici 3. Ova reklasifikacija je sukladna onoj koja je korištena u publikaciji „Stručni priručnik za procjenu utjecaja zahvata na velike zvjeri pojedinačno te u sklopu planskih dokumenata Verzija 1.0 - primjer vjetroelektrane (Kusak i sur. 2016) te se rezultati ovog rada direktno mogu dodati u spomenuti stručni priručnik.

Tablica 3. Vjerojatnosti (%) prisutnosti medvjeda s obzirom na osjetljivost i pogodnost staništa (Kusak i sur. 2016)

Vjerojatnost (%) prisutnosti medvjeda	Klase osjetljivosti staništa	Kategorija (značaj)
0-5	1	neprikladno
5-10	2	niska prikladnost
10-20	3	
20-30	4	
30-40	5	srednja prikladnost
40-50	6	
50-65	7	
65-80	8	visoka prikladnost
80-100	9	


Bilo je potrebno da se rasteru autocesta pridoda vrijednost 1 što predstavlja prepreku, odnosno neprikladno područje za medvjede. Nasuprot tome, prijelazima je pridodana vrijednost 9 što je označavalo veću vjerojatnost kretanja medvjeda. Raster modela distribucije reklasificiran je u 9 kategorija gdje je broj 1, kao i u slučaju autocesta, označavao neprikladno stanište za medvjede dok s povećanjem broja se povećava i prikladnost staništa. Broj 9 je predstavljao istu potpunu prikladnost kao i kod rastera prijelaza. Spojeni raster se zatim koristio za izradu modela koridora kojim je namjera bila vjerno prikazati sve koridore na području kretanja medvjeda. Nakon pripreme završnog rastera upotrijebljene su procedure Cost Distance i Cost Path. Uz to, korištene su i nasumično izabrane točke koje su bile u vektorskom obliku. Točke su odabrane tako da čine parove točaka sa jedne i druge strane postojećih autocesta na svim relevantnim dijelovima staništa medvjeda z Hrvatskoj. Procedure Cost Distance i Cost Path odredile su najkraću moguću udaljenost između dvije točke sa svake strane autoceste tako da je postalo vidljivo koje prijelaze medvjedi mogu koristiti prilikom prelaska autocesta.

Također, korišteni su i podaci o povremenoj i stalnoj prisutnosti medvjeda kao i karta Hrvatske podijeljena u 6 regija: Panonska i peripanonska Hrvatska, Gorski kotar, Istra i Primorje, Banovina, Kordun i Žumberak, Lika i Velebit te Dalmacija. Karte su bile potrebne kako bi se prikazala usporedba s drugim modelom, uspješnost samog modela kao i izračunale površine područja s obzirom na 9 klasa.

4. REZULTATI

4.1. Rezultati Maxent-a

Maxentom su dobiveni kumulativni i logistički izlazni podaci. Logistički tip izlaznog podatka prikazao je rezultat koji je nastao procjenom vjerojatnosti prisutnosti vrste s obzirom na okoliš. Neki od značajnijih izlaznih podataka bili su i stopa propusnosti predviđenog područja, krivulje koje prikazuju značajnost svake varijable kao i njihov pojedinačni utjecaj na kreiranje modela. Najvažniji izlazni podatak bio je ESRI ASCII format koji je predstavljao vjerojatnost distribucije vrste i koji je upotrijebljen za modeliranje koridora u ArcMap-u. Na slici 6. prikazan je neobrađen model dobiven u Maxent-u prije same obrade u ArcMap-u. Izrađen je na temelju lokacija obilježenih medvjeda te već prije spomenutih ekoloških varijabli. Prema rezultatima testiranja dobivenim Maxent-om vidljivo je da su ovim modelom najbolje obuhvaćene varijable koje model čine uspješnim.




Slika 6. Model vjerojatnosti pojavljivanja medvjeda, tj. prikladnosti staništa medvjeda dobiven pomoću programa Maxent (plava -0- nepogodno stanište, crvena -1- pogodno stanište)

Na slici 6. u donjem lijevom uglu prikazana je skala s vrijednostima modela i mogućnošću pojavljivanja medvjeda. Područja obojana toplijim bojama prikazuju veću vjerojatnost pojavljivanja medvjeda, dok plava boja prikazuje manju vjerojatnost.

Vidljivo je da su područja srednje i južne Dalmacije kao i slavonskih gora, Žumberačke gore i Medvednice, a gdje nema prisutnih zabilježenih medvjeda, ovim modelom prepoznata kao područja prikladna za život medvjeda.

Uz gore navedeni izlazni podatak, dobiveni su još neki vrlo važni statistički podaci koji su pomogli pobliže razumjeti model. Jedan od takvih izlaznih podataka je i stopa propusnosti predviđenog područja, prikazana na slici 7.




Slika 7. Stopa propusnosti predviđenog područja za medvjeda dobivena u Maxent-u (plavo - na temelju ulaznih podataka, svijetloplava - na temelju testnih podataka, crno - na temelju slučajne predikcije, crveno - vrijednost predikcije)

Kumulativni izlazni podatak predstavlja empirijsku raspodjelu podataka, te se tumači na stopi propusnosti. Kumulativni prag, tzv. „cumulative threshold“ je dio modela koji pokazuje vrijednosti iznad praga kontinuirane varijable koje bi trebale biti što sličnije promatranoj varijabli.

Na slici 7. jasno se vidi kako je stopa propusnosti vrlo blizu predviđenoj stopi propusnosti što nam ukazuje i sama definicija kumulativnog praga. Stopa propusnosti je negativna stopa koja prikazuje područja za koja je model predvidio postojanje neprikladnih uvjeta. Na slici je vidljivo

da izostavljanje u test uzorcima od 25% prati liniju i u vrlo je sličnom izostavljanju u ostalih 75% uzoraka što nam govori kako je odabrani model reprezentativan. Podaci su nepristrani, kao što bi i trebali biti te je predviđena stopa propusnosti u omjeru 1:1.

Na slici broj 8. prikazana je AUC krivulja za medvjeda. AUC (Area Under Curve) je jedan od važnijih izlaznih podataka Maxent-a.



Slika 8. Vrijednosti AUC na ROC krivulji za slučajno izabrana mjesta prisutnosti i mjesta odsutnosti iz testnog podskupa: crveno – na temelju ulaznih podataka (AUC = 0,928), plavo – na temelju test podataka (AUC = 0,927), crno - slučajna predikcija (AUC = 0,5)

Rezultat krivulje je blizu vrijednosti 1 (0,928) i krivulja je pod pravim kutom s obzirom na predviđenu krivulju što ukazuje da se radi o modelu koji je gotovo savršen.


Također, na grafu je prikazana Osjetljivost što predstavlja pozitivnu stopu, dok Specifičnost predstavlja negativnu stopu. Iako AUC krivulja nije dovoljna za procjenu modela, svakako daje jedan veliki doprinos procjeni uspješnosti modela.

U tablici 4. prikazan je udio relativne vrijednosti pojedine varijable u modelu. Iako je prvotno bilo 16 varijabli, jasno je vidljivo da nadmorska visina i udio šuma ponajviše doprinose modelu, a varijable ceste, udaljenost od cesta i udaljenost od naselja manje pridonose uspješnosti modela.

Tablica 4. Udio relativnog doprinosa modelu i permutacijske značajnosti po varijabli

Varijable	Udio doprinosa varijable	Permutacijski značaj
Nadmorska visina	65.1	83.4
Udio šuma	15.4	11.2
Gustoća cesta	11.8	2.1
Udaljenost od cesta	5.2	1.6
Udaljenost od naselja	2.4	1.6

Na slici 9. prikazani su rezultati Jackknife testiranja sa AUC vrijednošću. Iako se Maxent-om dobije više grafikona Jackknife testiranja, vrlo važno je testiranje svake varijable posebno s obzirom na AUC. Na slici primjećujemo kako ekološka varijabla nadmorska visina ima najveću vrijednost što znači da sadrži najkorisnije informacije za rezultat modela.

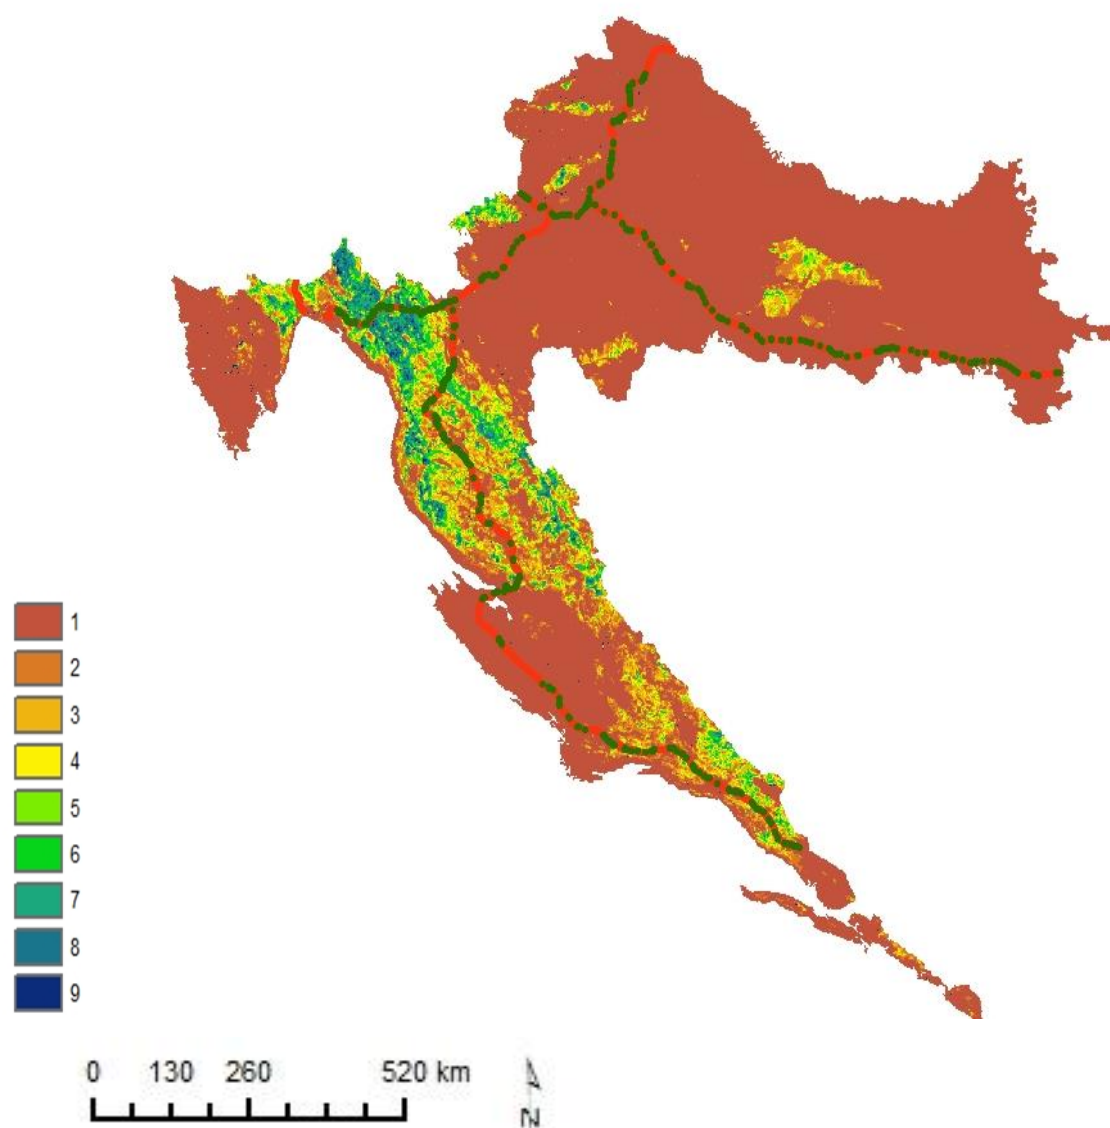


Slika 9. Rezultati Jackknife testiranja značaja pojedinačnih prediktivnih varijabli. Popis varijabli kao u Tablici 6. (svijetloplavo – model bez testirane varijable, plavo – model samo s testiranom varijablom, crveno – model sa svim varijablama)

Jackknife testiranje provedeno u ovoj analizi je vrsta testiranja pomoću kojeg se izrađuje model na način da se promatra svaka varijabla zasebno i na temelju samo jedne varijable radi testiranje. Isto se ponavlja za svaku izostavljajući druge. Testirajući na taj način, dobili smo informacije za svaku varijablu koje nam govore koliko je pojedino obilježje važno za distribuciju vrste i koliko pruža jedinstvenih informacija bitnih za izradu modela. Pristup se temelji na vrijednostima kumulativnog praga spomenutog ranije u radu (Baldwin 2009).

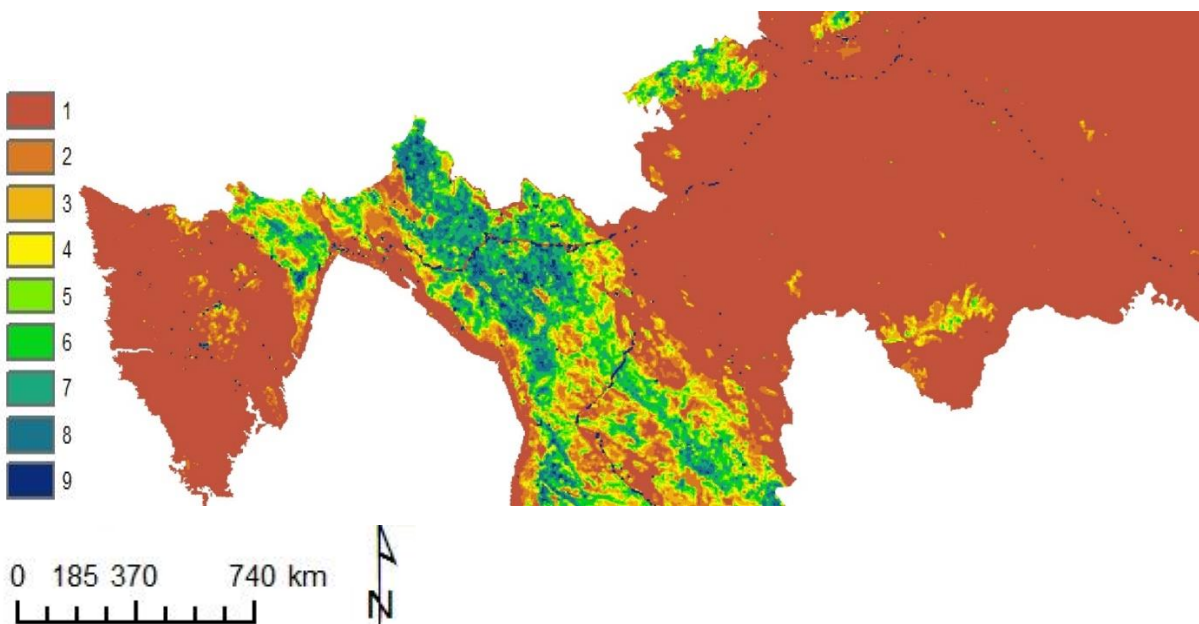
4.2. Rezultati modeliranja koridora u GIS-u

Nakon dobivanja modela Maxent-om, slika broj 10. pokazuje područje RH s kartom rasprostranjenosti, postojećim autocestama i prijelazima širine iznad 80 metara prije reklasifikacije. Područje Hrvatske je prema skali podijeljeno na pogodna i nepogodna područja. Plavom bojom prikazana su povoljna područja za medvjede, dok crvenom nepogodna. Također, postojeće autoceste su prikazane jarko crvenom bojom, a prijelazi su obojani tamnozeleno. Na taj način prikazano je postojeće stanje u Hrvatskoj kao i trasu autocesta u Hrvatskoj.



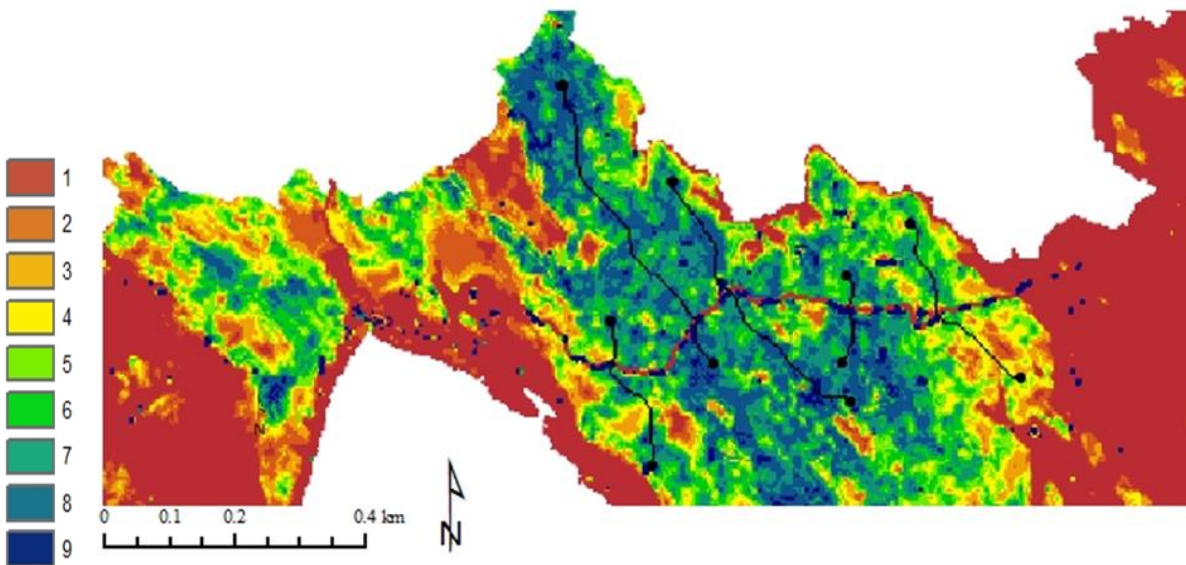
Slika 10. Prikaz karte s modelom staništa reklasificiranim u devet klasa, autocestama i prijelazima iznad 80 m (model staništa: plavo – pogodno stanište, smeđe - nepogodno; autoceste - crveno , prijelazi - tamnozeleni boja)

Na slici 11. nalazi se uvećan prikaz Gorskog kotara, kao i reklasificirani raster podijeljen u devet klasa na kojem se jasno vidi kako su povoljna staništa za medvjede prikazana plavom bojom kao i prijelazi. Crvenom bojom obojana su neprikladna područja kao i autoceste.




Slika 11. Spojeni rasteri u 1 zajednički klasificiran u 9 klasa
(plavo – pogodno stanište, smeđe – nepogodno)

Sljedeća slika (12.) također pokazuje područje Gorskog kotara, no s modeliranim koridorima. Točke označene crnom bojom odabrane su u glavnim kompleksima pogodnih staništa sa jedne i druge strane autoceste. Koridor koji spaja točke ide preko autoceste i pokazuje nam moguće kretanja medvjeda koji prelazeći s jedne strane autoceste na drugu koristi prijelaze. Izmodelirano je pet koridora koji predviđaju kretanje medvjeda preko prijelaza.



Slika 12. Prikaz područja Gorskog kotara s ucrtanim koridorima (plavo – pogodno stanište, smeđe – nepogodno, crno – nasumično izabrane točke, tamnozeleno – koridori)

Slika 13. prikazuje novonastale koridore na području Like. Izrađeno je 7 koridora koja povezuju povoljna staništa za medvjede. Na pojedinim koridorima jasno se uočava kako moguće kretanje medvjeda prati logičan slijed. No, ponekad zbog disperzije staništa se može dogoditi da pojedina jedinka koristi i nepovoljno područje. Razlog tome ponajviše je nedostatak i velika udaljenost između pogodnih prijelaza.



Slika 13. Prikaz područja Like i Velebita s ucrtanim koridorima (plavo – pogodno stanište, smeđe – nepogodno, crno – nasumično izabrane točke, tamnozeleno – koridori)

4.3. Izračun površina prikladnih staništa

Na sljedećim tablicama prikazan je izračun površina u ArcMap-u od podataka iz atributivnih tablica na temelju selekcije. Selekcija je vršena usporedbom lokacije i pojedinih značajki kako bi se izdvojila područja. Površina je izračunata uz pomoć opcije koja daje statistički pregled odabranih podataka. U tablici 5. je prikaz usporedbe dobivenih površina pomoću programa Mahalanobis (Kusak i sur. 2016) i reklasificiranog rastera dobivenog iz Maxent-a. Bitno je naglasiti kako je površina dobivena modeliranjem koje su proveli Kusak i sur. (2016) izračunata samo na područjima stalne i povremene prisutnosti medvjeda.

Tablica 5. Površina područja s obzirom na Mahalanobis (Kusak i sur. 2016), na stalnu i povremenu distribuciju i Maxent o ovisnosti o klasama osjetljivosti

KLASE OSJETLJIVOSTI	Površine staništa medvjeda (km²) na području povremene i stalne rasprostranjenosti medvjeda (Kusak i sur. 2016)	Površine staništa medvjeda (km²) na području povremene i stalne rasprostranjenosti dobiveno Maxent- om	Površine staništa medvjeda (km²) na području cijele kopnene Hrvatske
1	3977.6	507.32	40393.28
2	458.6	1510.41	3326.87
3	659.2	1497.73	2709.67
4	485.2	1317.2	2048.3
5	498.1	1118.45	1572.66
6	510.2	1020.32	1262.35
7	880.1	907.57	1019.63
8	1231.8	653.23	678.81
9	3211.1	87.24	131.98
UKUPNO	11911.9	8619.47	53147.55

U tablici 6. prikazana je površina na kojoj se medvjedi pojavljuju s obzirom na geografske regije. Kao i u tablici 5. površina je izračunata u odnosu na klase osjetljivosti staništa medvjeda.

Tablica 6. Površine (km²) staništa medvjeda u šest regija Hrvatske s obzirom na klase osjetljivosti staništa

KLASE OSJETLJIVOSTI	Panonska i peripanonska regija	Gorski kotar	Istra i Primorje	Banovina, Kordun i Žumberak	Lika i Velebit	Dalmacija	UKUPNO
1	3.25	100.28	11.23	3.1	935.55	167.44	1220.85
2	436.11	157	164.93	132.79	1141.64	1046.22	3078.69
3	323.82	166.13	140.41	123.81	1081.71	736.91	2572.79
4	239.32	202.73	117.02	102.29	857.02	421.83	1940.21
5	132.51	264.22	103.22	78.51	664.17	253.93	1496.56
6	57.53	327.04	84.15	61.67	525.24	138.17	1193.8
7	23.49	445.4	51.7	34.8	375.23	989.82	1920.44
8	5.65	390.1	22.26	8.16	238.54	675.08	1339.79
9	10.21	52.59	19.27	4.02	29.25	129.68	245.02
UKUPNO	1231.89	2105.49	714.19	549.15	5848.35	4559.08	15008.15

5. RASPRAVA

Model moguće distribucije medvjeda pokazao je gdje bi se sve medvjedi mogli nalaziti s obzirom na njihove potrebe za prostorom i dostupnost prostora s odgovarajućim osobinama u Hrvatskoj. Ti rezultati su u skladu s pretpostavkama uspješnog modela opisanog prethodno u radu. Prema dobivenom modelu, medvjedi bi mogli obitavati na prostorima na kojima ih trenutno nema u Hrvatskoj, a koja posjeduju sve uvjete za njihov život. Područje koje zadovoljava sve uvjete za njihov suživot s drugim vrstama, kao i da je dovoljno daleko od naseljenih područja je primjerice Papuk, jedna od slavonskih gora. Ovaj model ukazao je na činjenicu da se i na tim prostorima može očekivati prisutnost medvjeda te bi se trebala pružiti dovoljna pozornost pri planiranju budućih prometnica kako bi to područje moglo biti pogodno stanište. Izračunom površine povremene i stalne prisutnosti medvjeda prikazana je usporedba dva modela. Model iz Maxent-a ima manju površinu prikladnog područja u odnosu na model iz Mahalanobis-a (Kusak i sur. 2016). Analiza izračunatih površina omogućila je točnije podatke vezane za kretanje medvjeda. Iako su dobiveni rezultati različiti, bitno ih je uspoređivati te u istraživanjima koristiti što više programa kako bi se dobili precizniji podaci o stvarnom staništu medvjeda u Hrvatskoj. To je od iznimne važnosti za zaštitu i očuvanje cjelovitosti staništa medvjeda.

Stopa izostavljanja predviđenog područja pomoću kumulativnog praga pokazala je da se model i odabrane varijable pomoću kojih je izrađen podudaraju s predviđenom stopom. *Test* podaci i *training* podaci su vrlo blizu jedan drugome kao i predviđenim podacima što ukazuje da su ulazne varijable ispravno odabrane.

Prema rezultatima ROC krivulje, odnosno prostoru ispod nje (AUC) vidljivo je kako se radi o modelu koji odlično opisuje pojavu. Ukoliko bi ta vrijednost bila manja nego što je, to bi dovelo u pitanje uspješnost modela kojeg bi trebalo iznova ponavljati mijenjajući postavke programa dok ta vrijednost ne bude bliža 1. Dobra ROC krivulja predstavlja nužan uvjet koji mora biti zadovoljen kako bi se dobiveni rezultati mogli iskoristiti za daljnja testiranja. Postoje rasprave između brojnih autora o visini AUC vrijednosti, naime ponekad te iste vrijednosti nisu jedini uvjet koji pokazuje da li je model bolji od onoga s manjim vrijednostima te u obzir treba uzeti i druge statističke pokazatelje (Lobo i sur. 2007).

Jackknife testiranjem utvrdila se značajnost svake pojedine varijable kada se izostave ostale, tj. utjecaj na model koji ima svako obilježje kada se promatra zasebno. Varijabla nadmorske visine značajna je u modelu jer medvjedi obitavaju na višim nadmorskim visinama (Bartol i sur. 2016). Također, varijabla koji opisuje udio šuma se pokazala značajnom što je i u skladu s očekivanjima budući da medvjedi borave na šumovitim i brdovitim područjima (Huber i sur. 2008). Rezultati Jackknife testiranja s obzirom na AUC važni su jer korisniku daju informaciju da li promatrana varijabla ima utjecaj na model i u kojoj mjeri. Povezano s time, ukoliko njena značajnost nije na odgovarajućoj razini, bolje je da se izostavi iz daljnjeg promatranja. Varijable koje nisu značajne opterećuju model a ne pridonose povećanju njegove signifikantnosti te nema razloga da ih se uzima u obzir. Ponekad nam ovakav način testiranja otkriva da li varijable promatrane zajedno imaju veću značajnost nego kad se promatraju zasebno (Phillips 2006, Baldwin 2009).

Unošenjem izlaznog podatka modela distribucije u ArcMap, dobili smo kartu Hrvatske s prikazanim područjima koja imaju veću i manju vjerojatnost pojavljivanja medvjeda. Nakon dodavanja tom modelu još i autocesta i prijelaza kao otežavajućih (autoceste) i pogodujućih (prijelazi preko autocesta) činitelja, dobiven je klasificirani raster koji je pokazivao što medvjedima predstavljaju autoceste (100%-tnu prepreku), a što prijelazi. Prijelazi uključujući i mostove, vijadukte, prolaze, tunele i zelene mostove su mjesta koja imaju najveću vjerojatnost za korištenje od strane medvjeda za prelaženje preko autocesta. Uz to, na karti su prikazana područja veće mogućnosti pojavljivanja medvjeda. Najvažnija spoznaja do koje sam došla pomoću Least Cost Path modeliranja i pripremljene karte klasa staništa je prikaz mogućeg kretanja medvjeda njihovim staništem, uz korištenje prijelaza preko autocesta. Važno je bilo prikazati njihovo potencijalno kretanje kako bi se pratile moguće buduće ugroze tih kretanja. Ta informacija bitna je za budućnost i potencijalnu gradnju novih infrastrukturnih objekata, kao što su vjetroparkovi, skijališta, nove ceste i sl. Naime, ovakav tip modeliranja može pokazati koliko bi izgradnja nove prometnice na području stalnog obitavanja medvjeda utjecalo na mogućnost kretanja tj. cjelovitost njihovog staništa. Ukoliko se nedovoljno pažnje i vremena posveti istraživanju područja prije njihove izgradnje, posljedice će se osjećati godinama poslije zbog infrastrukture koja trajno narušava prepoznatu cjelovitost staništa medvjeda. Dobiveni model prikladnosti, tj. osjetljivosti staništa i prepoznati koridori za kretanje medvjeda, mogu biti izravno upotrijebljeni kao podloge kod izrada studija koje ocjenjuju mogući učinak nekog infrastrukturnog projekta na medvjede.

6. ZAKLJUČCI

1. Na području kopnene Hrvatske ukupna površina staništa medvjeda visoke prikladnosti je 1830.42 km² (3.44%), srednje prikladnosti je 4883.31 km² (9.19%), niske prikladnosti je 6036.54 km² (11.36%), dok je neprikladnih staništa 40393.28 km² (76.01%).
2. Na području stalne i povremene prisutnosti medvjeda u Hrvatskoj, ukupna površina staništa medvjeda visoke prikladnosti je 1648.04 km² (19.12%), srednje prikladnosti je 3455.97 km² (40.09%), niske prikladnosti je 3008.14 km² (34.89%), dok je neprikladnih staništa 507.32 km² (5.90%).
3. Na području slavonskih gora, Medvednice, Žumberka i Biokova postoje prikladna staništa za medvjeda, ali njihovo pojavljivanje na tim područjima nije vjerojatno jer su izolirana, tj, nema dobrih koridora do njih.
4. Na području stalne i povremene prisutnosti medvjeda u Hrvatskoj, modeliranjem je prepoznato 12 koridora preko postojećih autocesta.
5. Cjelovitost staništa medvjeda u Hrvatskoj je očuvana, unatoč autocestama.
6. Izrađena je karta koja prikazuje prikladnost staništa medvjeda i moguće koridore kretanja medvjeda.
7. Ovaj diplomski rad i svi rezultati iznijeti u njemu mogu poslužiti kao podloga za buduće planiranje infrastrukturnih projekata, a uzimajući u obzir potrebe medvjeda za kvalitetnim i cjelovitim staništem.

7. LITERATURA

Anderson R. P., Gómez-Laverde M., Townsend Peterson A. (2002): Geographical distributions of spiny pocket mice in South America: insights from predictive models. *Global Ecology & Biogeography*, **11**, 131–141.

Anonimus (2008): Ekološka mreža Natura 2000. <http://zagorje-priroda.hr/ekoloska-mreza-uvod> (pristupila 03.10.2016.)

Anonimus (2009): Medvjed u lovištu Klek obilježen ogrlicom za praćenje kretanja. http://www.ldklek-ogulin.hr/?subaction=showfull&id=1255967044&archive=&start_from=&ucat=& (pristupila 25.11)

Anonimus (2016): Ekološka mreža. <http://www.natura-histrica.hr/hr/ekoloska-mreza> (pristupila 03.10.2016)

Anonimus (2016): „Zeleni mostovi“. <http://www.life-vuk.hr/prijelazi-za-divlje-zivotinje/prometnice-i-velike-zvijeri/zeleni-mostovi-192.html> (pristupila 5.12)

Baldwin R. A. (2009): Use of Maximum Entropy Modeling in Wildlife Research. *Entropy* 2009, **11**(4), 854-866.

Bartol M., Černe R., Krofel M., Wilson S.M., Stergar M., Huber D., Berce T., Jerina K., Majić Skrbinišek A., Knauer F., Rauer G., Kavčič I., Mohorović M., Marinko U., Groff C., Luštrik R., Reljić S. (2016): Smeđi medvjed u Dinaridima i Alpama. Brošura izrađena u okviru LIFE DINALP BEAR. Veterinarski fakultet, Zavod za biologiju, Zagreb

Chapron G., Kaczensky P., Linnell J.D.C., Arx M. von, Huber D., Andrén H., López-Bao J.V., Adamec M., Álvares F., Anders O., Balčiauskas L., Balys V., Bedő P., Bego F., Blanco J.C., Breitenmoser U., Brøseth H., Bufka L., Bunikyte R., Ciucci P., Dutsov A., Engleder T., Fuxjäger C., Groff C., Holmala K., Hoxha B., Iliopoulos Y., Ionescu O., Jeremić J., Jerina K., Kluth G., Knauer F., Kojola I., Kos I., Krofel M., Kubala J., Kunovac S., Kusak J., Kutal M., Liberg O., Majić A., Männil P., Manz R., Marboutin E., Marucco F., Melovski, D., Mersini, K., Mertzanis Y., Mysłajek R.W., Nowak S., Odden J., Ozolins J., Palomero G., Paunović M., Persson J., Potočnik H., Quenette P.-Y., Rauer G., Reinhardt I., Rigg R., Ryser A., Salvatori V., Skrbinišek T., Stojanov A., Swenson J.E., Szemethy L., Trajçe A., Tsingarska-Sedefcheva E., Váňa M., Veeroja R., Wabakken P., Wölfl M., Wölfl S., Zimmermann F., Zlatanova D., Boitani L. (2014): Recovery of large carnivores in Europe's modern human-dominated landscapes. *Science* (80-.). 346, 1517–1519. doi:10.1126/science.1257553

Dudík M., Phillips P.J., Schapire R.E. (2005): Correcting sample selection bias in maximum entropy density estimation. *Advances in Neural Information Processing Systems*, **18**, 323-330.

Elith J., Graham, C.H., Anderson R.P., Dudík M., Ferrier S., Guisan A., Hijmans R.J., Huettmann F., Leathwick J.R., Lehmann A., Li J., Lohmann L.G., Loiselle B.A., Manion G.,

Moritz C., Nakamura M., Nakazawa Y., Overton J.M., Peterson A.T., Phillips S.J., Richardson K.S., Scachetti-Pereira R., Schapire R.E., Soberón J., Williams S., Wisz M.S., Zimmermann N.E. (2006): Novel methods improve prediction of species' distributions from occurrence data. *Ecography*, **29**, 129-151.

Elith J., Phillips S.J., Hastie T., Dudik M., Chee, Y. E., Yates, C.J. (2011): A statistical explanation of MaxEnt for ecologists. *Diversity and Distributions*, **17**, 43–57

Graham C.H., Ferrier S., Huettman F., Moritz C., Peterson A.T. (2004): New developments in museum-based informatics and applications in biodiversity analysis. *Trends in Ecology and Evolution*, **19**, 497–503.

Gužvica G., Šver L. (2006): Preliminarni rezultati praćenja prijelaza životinja zelenim mostom Osmakovac u Dalmaciji. *Drypis* 2/1,2

Halavuk T. (2013): Zoogeografska analiza rasprostranjenosti gujavica (Lumbricidae) na području Hrvatske, Diplomski rad

Huber Đ., Roth H.U. (1993): Movements of European brown bears in Croatia. *Acta Theriologica* **38** (2): 151-159

Huber Đ. (1997): Izvješće o medvjedu R8 "Mate", Lovac (1331-0275) **1, 4**; 27-30

Huber Đ. (2001): Istraživanje medvjeda u Hrvatskoj. Za „LOVSTVO“ (Za Hrvatski lovački savez)

Huber Đ. (2002): Smeđi medvjed. Za „Lovački priručnik“

Huber Đ., Tvrtković N., Dušek A., Štahan Ž., Pavlinić I., Krivak Obadić V., Budak Rajčić J. (2002): Propusnost cesta za životinje (Prijedlog smjernica za projektiranje). Institut građevinarstva Hrvatske d.d, Zagreb

Huber Đ., Jakšić Z., Frković, A., Štahan Ž., Kusak J., Majnarić D., Grubešić M., Kulić B., Sindičić M., Majić Skrbinišek A., Lay V., Ljuština M., Zec D., Laginja R., Francetić I. (2008): Plan gospodarenja smeđim medvjedom u Republici Hrvatskoj. Ministarstvo regionalnog razvoja, šumarstva i vodnoga gospodarstva, Uprava za lovstvo

Jaynes E. T. (1957): Information Theory and Statistical Mechanics. *Physical Review*, vol. 106, no. 4, str. 620-630

Kramer-Schadt S., Niedballa J., Pilgrim J.D., Schroder B., Lindenborn J., Reinfelder V., Stillfried M., Heckmann I., Scharf A.K., Augeri D.M., Cheyne S.M., Hearn A.J., Ross J., Macdonald D.M., Mathai J., Eaton J., Marshall A.J., Semiadi G., Rustam R., Bernard H., Alfred R., Samejima H., Duckworth J.W., Breitenmoser-Wuersten C., Belant J.L., Hofer H., Wilting A. (2013): The importance of correcting for sampling bias in MaxEnt species distribution models. *Diversity and Distributions*, (Diversity Distrib.), 1–14

Kusak J., Huber D., Frković A. (2000): The effects of traffic on large carnivore populations in Croatia. *Biosphere Conservation*, br. 3, 35-39.

Kusak J., Huber Đ., Trenc N., Desnica S., Jeremić J. (2016): Smjernice za procjenu utjecaja zahvata na velike zvijeri pojedinačno te u sklopu planskih dokumenata. Hrvatska agencija za okoliš i prirodu, 64 str.

Lobo J.M., Jimenez-Valverde A., Real R. (2007): AUC: a misleading measure of the performance of predictive distribution models. *Global Ecology & Biogeography*, 17, 145– 151.

Merow C., Smith M. J., Silander J. A. (2013): A practical guide to MaxEnt for modeling species distributions: what it does, and why inputs and settings matter. *Ecography* **36**, 1058–1069

Phillips P. J., Anderson R. P., Schapire R. E. (2006): Maximum entropy modeling of species geographic distributions. *Ecological Modelling*, **190**, 231-259, 2006.

Selanec I.(2012): Analiza staništa čaglja (*Canis aureus* Linnaeus 1758) u Hrvatskoj, Diplomski rad, PMF Zagreb

Swenson J. E., Gerstl N., Dahle B., Zedrosser A. (2000): Action Plan for the conservation of the Brown Bear (*Ursus arctos*) in Europe. Convention on the Conservation of European Wildlife and Natural Habitats (Bern Convention), Nature and environment, No. 114

Toskić A. (2015): Geografski informacijski sustav, Predavanja za Znanosti o okolišu

Young N., Carter L., Evangelista P.(2008): A MaxEnt Model v3.3.3e Tutorial (ArcGIS v10).

<http://www.geografija.hr/hrvatska/utjecaj-izgradnje-autocesta-na-fragmentaciju-stanista/> (pristupila 8.11)

<http://www.savjetodavna.hr/savjeti/14/487/zastita-stoke-od-zvijeri/> (pristupila 8.11)

http://ec.europa.eu/environment/nature/conservation/species/carnivores/conservation_status.htm (pristupila 25.11)

<http://www.dzrp.hr/ekoloska-mreza/natura-2000/ekoloska-mreza-rh-natura-2000-1300.html> (pristupila 8.11)

ŽIVOTOPIS

OSOBNJE INFORMACIJE

Ivana Hazdovac

 Kamenarka, 28B, 10000 Zagreb (Hrvatska)

 098849432

 ivana.hazdovac@gmail.com

RADNO ISKUSTVO

01/03/2015–01/03/2016

Potpredsjednica za projekte

IAAS Croatia - Hrvatsko udruženje studenata agronomije i srodnih znanosti, Zagreb (Hrvatska)

01/07/2011–01/10/2016

recepcionarka - sezonski

Kamp "Lovor", Kozarica bb, Mljet (Hrvatska)

- opća komunikacija s gostima
- prijava i odjava gostiju
- naplata računa

OBRAZOVANJE I OSPOSOBLJAVANJE

01/10/2014–danas

Diplomski studij Znanosti o okolišu

Prirodoslovno - matematički fakultet, Zagreb (Hrvatska)

01/10/2011–01/10/2014

Prvostupnica struke Znanosti o okolišu

Prirodoslovno - matematički fakultet, Zagreb (Hrvatska)

01/09/2007–01/06/2011

Srednja stručna sprema

IV. Gimnazija, Zagreb (Hrvatska)

OSOBNJE VJEŠTINE

Materinski jezik

hrvatski

Ostali jezici

engleski

talijanski

RAZUMIJEVANJE		GOVOR		PISANJE
Slušanje	Čitanje	Govorna interakcija	Govorna produkcija	
B2	B2	B2	B2	B2
B1	B2	A2	A1	A2

Stupnjevi: A1 i A2: Početnik - B1 i B2: Samostalni korisnik - C1 i C2: Iskusni korisnik
Zajednički europski referentni okvir za jezike

Komunikacijske vještine

- dobre komunikacijske vještine stečene tijekom rada na recepciji, kao i na seminarima i tjednima razmjene s drugim fakultetima
- radom u studentskoj udruzi na raznim projektima naučila sam kako se radi u timu i pišu izvješća

Organizacijske / rukovoditeljske vještine

- glavna organizatorica projekta "Green Mediterranean" održan 2015. na Mljetu i u dolini Neretve
- jedna od glavnih organizatora projekta "Green perspective of an urban area" održanog 2015. u Zagrebu
- jedna od organizatora prikupljanja odjeće i hrane za dom za nezbrinutu djecu povodom blagdana (2014., 2015. i 2016.)

Digitalna kompetencija

SAMOPROCJENA				
Obrada informacija	Komunikacija	Stvaranje sadržaja	Sigurnost	Rješavanje problema
Iskusni korisnik	Iskusni korisnik	Iskusni korisnik	Samostalni korisnik	Iskusni korisnik

Informacijsko-komunikacijske tehnologije - tablica za samoprocjenu

- vješto baratanje Microsoft Office alatima
- poznavanje i rad u GIS softveru i programu Maxent

Vozačka dozvola

B

DODATNE INFORMACIJE

Članstva

- IAAS Croatia - Hrvatsko udruženje studenata agronomije i srodnih znanosti (2015. - 2016. Potpredsjednica za projekte, 2016. - 2017. član Nadzornog odbora)